基于神经网络的薄壁件铣削动力学参数预测

王大振　李　琪　王　亮
（西安航天动力测控技术研究所，西安 710025）

摘要：精确预测薄壁件铣削过程中工件的时变动力学参数是选择无颤振切削参数的基础。本文提出了基于三层神经网络的曲面薄壁件铣削时变动力学参数的预测方法。首先利用壳单元将薄壁件进行离散化，将离散单元结点处工件厚度作为输入参数，工件前三阶固有频率作为输出参数，构建三层神经网络。然后将壳单元有限元模型计算结果作为训练样本，训练得到神经网络模型。模态测试实验结果表明，有限元模型对工件固有频率预测的最大误差约为 4%；与有限元模型相比，神经网络模型的最大预测误差为 0.409%，因此神经网络模型的最大预测误差约为 4%。同时，神经网络模型训练时间约为 10 s；当预测的切削状态数量为 150 时，预测时间仅为 0.002 s。在保证计算精度的前提下，三层神经网络模型可大幅提高计算效率。

关键词：薄壁件；铣削颤振；动力学参数；壳单元；神经网络
中图分类号：TP311.1　**文献标识码**：A
DOI:10.20177/j.cnki.htzzjs.2024.02.011

Predicting the Dynamic Parameters of the Workpiece during Milling of Thin-walled Parts Based on Neural Network

Wang Dazhen　Li Qi　Wang Liang
(Xi’an Institute of Aerospace Power Measurement and Control Technology, Xi’an 710025)

Abstract: Accurately predicting the time-varying dynamic parameters of workpieces during milling of thin-walled parts is the basis for selecting chatter-free cutting parameters. This paper proposes a three-layer neural network based method for predicting time-varying dynamic parameters of workpiece during milling of curved thin-walled parts. Firstly, the thin-walled part is discretized using shell elements, and the thickness of the workpiece at the discrete element nodes is taken as the input parameter, while the first three natural frequencies of the workpiece are taken as the output parameters to construct a three-layer neural network. Then, the results of finite element model built by the shell element are used as training samples to train the neural network model. Modal testing results show that the maximum error of the finite element model in predicting the natural frequencies of the workpiece is about 4%. Compared with the results of finite element model, the maximum prediction error of the neural network model is 0.409%. Therefore, the maximum prediction error of the neural network model is about 4%. At the same time, the training time of the three-layer neural network model is approximately 10 s. When the number of predicted cutting states is 150, the prediction time is only 0.002 s. The three-layer neural network model can greatly improve computational efficiency while ensuring calculation accuracy.

Key words: thin-walled parts; milling chatter; dynamic parameters; shell elements; neural networks

1　引言

虽然薄壁件已广泛应用于航空航天领域，但是在薄壁件精加工阶段易发生切削颤振，导致工件加工质量差。为提高加工质量，需对切削过程中的颤振进行抑制。通过构建稳定叶瓣图来选择切削参数是抑制切削颤振的有效方法。在薄壁件精加工阶段，工件的动力学参数会随材料的切除发生变化，为提高模型的准

收稿日期：2024-03-06

确性，必须考虑材料去除对工件动力学参数的影响。本文提出了基于神经网络的薄壁叶片铣削时变动力学参数预测模型。

研究人员已在薄壁件切削时变动力学参数预测方面开展了相关研究，并取得了相应的成果。Yang Yun 等[1]基于结构模态参数修改提出了一种计算刀具切削到任意位置时工件模态参数的方法，该方法仅通过对初始工件的 FEM 模型进行模态分析来计算加工过程中工件的模态振型和固有频率，无需对每个切削状态的工件进行重新建模和重新划分网格。随后研究了时变模态参数对薄壁件铣削稳定性的影响。Yang Yun 等[2]针对大型薄壁工件的精/半精加工提出了一种分解−缩聚法来预测工件的模态参数。该方法将工件分解为已加工的工件和要去除的材料，利用结构动态修改技术来更新要去除材料的时变模型，通过这种方式，避免了对工件有限元模型的重建。Dang Xuebin 等[3]以减少加工中工件质量矩阵和刚度矩阵的自由度为目的，结合自由度缩减和结构修改技术提出了一种计算加工中工件 FRFs 的方法。研究了刀具位置和材料去除对工件固有频率和模态振型等模态参数的影响，并针对平板薄壁件和曲面薄壁件铣削建立了三维稳定切削叶瓣图。

在复杂曲面叶片零件加工方面，Budak 等[4]利用商业有限元软件基于三维立方体单元建立叶片结构有限元模型，获得工件的初始 FRFs；通过加工过程中被切除的单元更新工件的模态参数。Zhang Xiaoming 等[5]采用矩阵摄动法计算叶片结构的模态参数。Luo Ming 等[6]采用数值仿真的方法研究薄壁叶片铣削过程中工件模态参数的演化和切削稳定性。Tian Weijun 等[7]通过矩阵摄动法计算薄壁叶片铣削过程中工件的固有频率。鞠岗岗[8]针对复杂曲面变厚度薄壁件多轴铣削，将整个加工过程沿刀具路径离散为有限个单元，将切削加工过程看作是离散单元逐个去除掉的过程，然后应用 Sherman-Morrison-Woodbury 公式预测加工过程中工件模态参数变化规律。Tuysuz 等[9]基于降阶结构矩阵解耦和模态振型摄动，提出了一种预测叶片零件切削过程中工件瞬时模态参数的模型，并通过切削试验和 FRFs 测试对所提出的模型进行了验证。刘一龙[10]根据理论力学和浅壳理论，采用解析方法求解叶轮叶片加工过程中工件模态参数的变化情况。

综上所述，在曲面叶片研究方面，文献[6−7]将曲面叶片结构简化为平板结构，然而平板结构和曲面叶片零件的力学特性差异较大，这会造成较大的计算误差。文献[4]采用三维立方体单元对薄壁叶片进行有限元建模，会导致模型自由度较大，且利用有限元软件对切削过程进行仿真分析非常耗时。文献[10]所提出的方法需要根据边界条件假定工件满足的振动方程，若假定的振动方程形式不合理，则计算误差较大，该研究求解得到的前两阶模态固有频率的最大误差为 8%。文献[5]基于矩阵摄动法对叶片结构固有频率进行预测，最大误差为 7.3%，误差较大。为适用曲面叶片的加工需求，需建立考虑叶片曲面特征的工件模态参数预测模型，同时需保证计算精度和计算效率。

神经网络已广泛应用于切削力预测、刀具磨损预测和工件表面粗糙度预测[11−15]。本文针对曲面薄壁叶片结构，基于壳单元有限元模型和三层神经网络提出了考虑工件几何形状的薄叶片铣削时变动力学参数预测方法。

2 基于神经网络的动力学参数预测模型

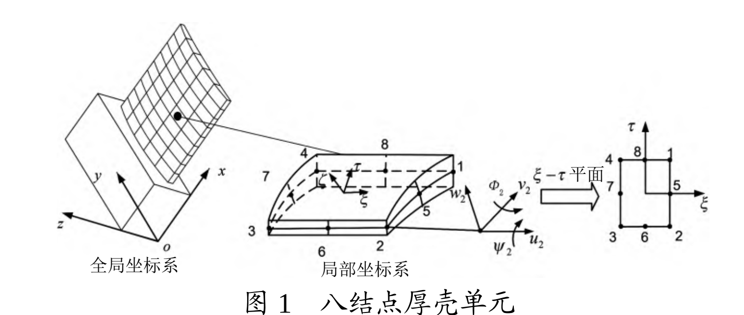


图 1 八结点厚壳单元

采用图 1 所示的八结点后壳单元对薄壁件进行离散化，进而采用图 2 所示的三层神经网络进行薄壁叶片铣削动力学参数预测。

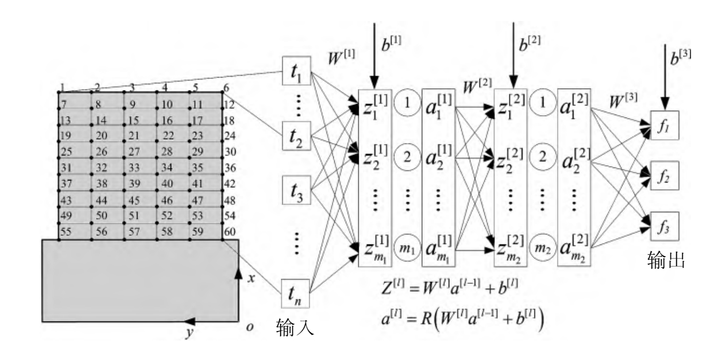


图 2 神经网络结构图

以单个样本点为例，描述计算过程。输入量 t 为单元结点厚度，输出变量 f 为工件前三阶固有频率，表示为：

$$t = \begin{bmatrix} t_1 & t_2 & \cdots & t_n \end{bmatrix}^T$$
$$f = \begin{bmatrix} f_1 & f_2 & f_3 \end{bmatrix}^T \tag{1}$$

激活函数采用 ReLU 函数，其表示为：

$$R(x) = \max(0, x) \tag{2}$$

由输入量t，第一层网络的权重矩阵$W^{[1]}$和偏置量$b^{[1]}$，以及激活函数计算得到：

$$Z^{[1]} = \begin{bmatrix} w_{1,1}^{[1]} & w_{1,2}^{[1]} & \cdots & w_{1,n}^{[1]} \\ w_{2,1}^{[1]} & w_{2,2}^{[1]} & \cdots & w_{2,n}^{[1]} \\ \vdots & \vdots & \ddots & \vdots \\ w_{m_1,1}^{[1]} & w_{m_1,2}^{[1]} & \cdots & w_{m_1,n}^{[1]} \end{bmatrix} \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_n \end{bmatrix} + b^{[1]} = W^{[1]} t + b^{[1]},$$
$$a^{[1]} = R(Z^{[1]}) \tag{3}$$

由第一层网络的输出量$a^{[1]}$，第二层网络的权重矩阵$W^{[2]}$和偏置量$b^{[2]}$，以及激活函数计算得到：

$$Z^{[2]} = \begin{bmatrix} w_{1,1}^{[2]} & w_{1,2}^{[2]} & \cdots & w_{1,m_1}^{[2]} \\ w_{2,1}^{[2]} & w_{2,2}^{[2]} & \cdots & w_{2,m_1}^{[2]} \\ \vdots & \vdots & \ddots & \vdots \\ w_{m_2,1}^{[2]} & w_{m_2,2}^{[2]} & \cdots & w_{m_2,m_1}^{[2]} \end{bmatrix} \begin{bmatrix} a_1^{[1]} \\ a_2^{[1]} \\ \vdots \\ a_{m_1}^{[1]} \end{bmatrix} + b^{[2]} = W^{[2]} a^{[1]} + b^{[2]},$$
$$a^{[2]} = R(Z^{[2]}) \tag{4}$$

由第二层网络的输出量$a^{[2]}$，第三层网络的权重矩阵$W^{[3]}$和偏置量$b^{[3]}$计算得到：

$$f = \begin{bmatrix} f_1 \\ f_2 \\ f_3 \end{bmatrix} = \begin{bmatrix} w_{1,1}^{[3]} & w_{1,2}^{[3]} & \cdots & w_{1,m_2}^{[3]} \\ w_{2,1}^{[1]} & w_{2,2}^{[1]} & \cdots & w_{2,m_2}^{[1]} \\ w_{3,1}^{[1]} & w_{3,2}^{[1]} & \cdots & w_{3_1,m_2}^{[1]} \end{bmatrix} \begin{bmatrix} a_1^{[2]} \\ a_2^{[2]} \\ \vdots \\ a_{m_2}^{[2]} \end{bmatrix} + b^{[3]} = W^{[3]} a^{[2]} + b^{[3]} \tag{5}$$

工件固有频率预测值与名义值之间的均方差损失函数表示为：

$$L = \frac{1}{2} \left\| f - \tilde{f} \right\|^2 \tag{6}$$

从而将薄壁件铣削动力学参数预测转化成优化问题：

$$\theta^* = \arg\min_{\theta} L(\theta) \tag{7}$$

其中，参数θ表示神经网络的权重矩阵W和偏置向量b，采用最速下降法迭代求解参数θ。

损失函数L关于权重矩阵W和偏置向量b的偏导数表示为：

$$\frac{\partial L}{\partial W^{[3]}} = (f - \tilde{f})(a^{[2]})^T \tag{8}$$

$$\frac{\partial L}{\partial W^{[2]}} = (W^{[3]})^T (f - \tilde{f})(a^{[1]})^T \tag{9}$$

$$\frac{\partial L}{\partial W^{[1]}} = (W^{[2]})^T (W^{[3]})^T (f - \tilde{f})(t)^T \tag{10}$$

$$\frac{\partial L}{\partial b^{[3]}} = f - \tilde{f} \tag{11}$$

$$\frac{\partial L}{\partial b^{[2]}} = (f - \tilde{f})^T W^{[3]} \tag{12}$$

$$\frac{\partial L}{\partial b^{[1]}} = (f - \tilde{f})^T W^{[3]} W^{[2]} \tag{13}$$

采用最速下降法迭代更新参数：

$$W = W - \eta \frac{\partial L}{\partial W},$$
$$b = b - \eta \frac{\partial L}{\partial b} \tag{14}$$

计算得到权重矩阵W和偏置向量b后，将其代入式（1）～式（3）计算薄壁件固有频率。

3 薄壁件铣削动力学参数预测与验证

3.1 有限元模型计算及试验验证

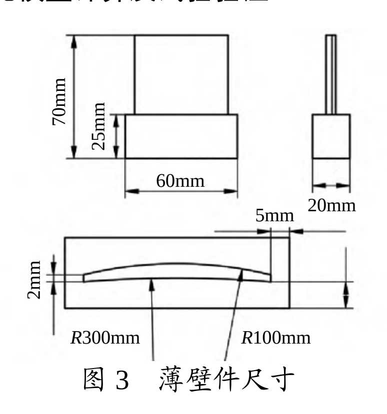


图 3 薄壁件尺寸

研究对象的尺寸如图 3 所示，对应的工件如图 4 所示，其材料是钛合金 TC4，密度为 4500 kg/m^3，弹性模量为 104 GPa，泊松比为 0.305。由于在加工过程中叶片的基座被夹具固定，为减少叶片有限元模型的自由度，只对叶片的叶型进行有限单元法建模。

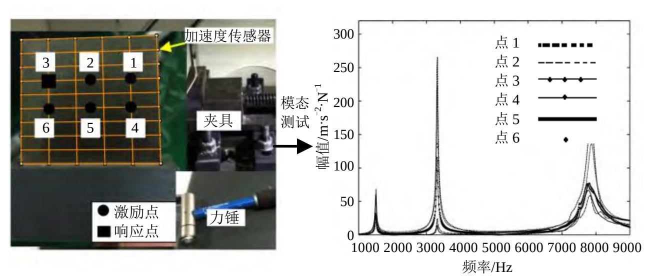


图 4　薄壁件铣削模态测试试验

基于壳单元的有限元模型[16]适用于壳体的薄壁结构，使用 Matlab 软件对叶片进行有限元建模。将叶片厚度 z 方向的单元数量设置为 1，将 y 方向的单元数量设置为 5。通过将 x 方向单元数量从 6 增加到 9 的方式对模型计算得到的固有频率进行收敛性分析。假设当前模型和前一模型计算得到的频率的变化量小于 0.1%时，计算结果达到收敛。经计算当 y 方向和 x 方向的壳单元数量分别为 5 和 8 时，计算得到的固有频率达到收敛。本文将模型 z 方向的单元数量设置为 1，将 y 方向的单元数量设置为 5，将 x 方向的单元数量设置为 9。

为验证所提方法的精确性，在五轴加工中心 JD GR200-A10SH 上进行薄壁件铣削和模态测试试验，其最大主轴转速为 28000 r/min，见图 4。为与叶片实际加工中采用的加工方式相一致，实验中叶片采用双面铣削。实验中采用直径为 8 mm 的 4 齿球头铣刀，主轴转速为 3000 r/min，进给速度为 300 mm/min，轴向切深为 5 mm，径向切深为 0.2 mm。

测试中采用的力锤型号为 Dytran Model 5800B，加速度传感器型号为 Dytran 3224A1，数据采集系统为 ECON-AVANT-8008，并采用 Econ 公司开发的模态分析软件提取工件的动力学参数。为保证测试的可信度和减少测试时间，对 6 个切削阶段的工件进行模态测试。Step 0 表示未切削时的初始工件状态，从 Step1 到 Step5 分别表示沿 x 方向切除深度为 5 mm、10 mm、15 mm、20 mm 和 25 mm 的材料。

本文采用固定传感器移动力锤的测试方法，传感器的黏贴位置和锤击测试点如图 4 所示，其中点 3 是所有测试的响应点，称作参考点。根据叶片的结构特征，在每个测试点沿着叶片 z 方向进行锤击。

将有限元模型计算得到的铣削过程中工件固有频率与由测试得到的工件固有频率进行对比分析，其相对误差表示为：

$$\eta_1 = \frac{f_{\mathrm{FEM}} - f_{\mathrm{Test}}}{f_{\mathrm{Test}}} \times 100\% \tag{15}$$

式中，f_{FEM} 和 f_{Test} 分别表示由壳单元有限元模型和模态测试获得的工件频率。计算结果如表 1 所示，与测试结果相比，由壳单元有限元模型计算得到结果的最大误差分别为 2.51%、2.53%、3.42%、4.04%、4.01%、3.81%。通过试验分析可知，壳单元有限元模型方法可以对铣削过程中叶片时变动态参数进行有效预测。

表 1　有限元模型[16]和锤击试验获得工件频率对比

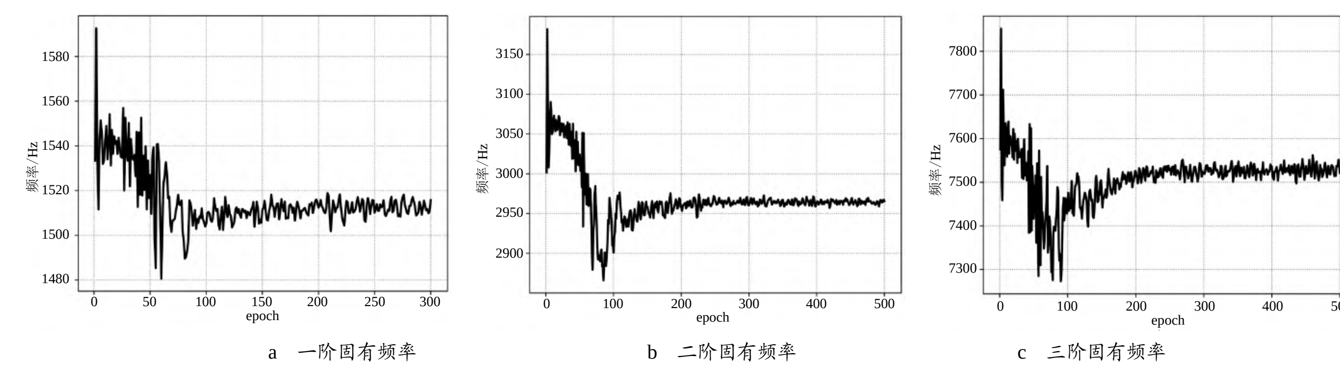
切削步	模态	1	2	3
0	模态测试	1535	3290	8152
	有限元模型	1574	3265	8293
	η_1/%	2.51	−0.76	1.72
1	模态测试	1552	3313	8094
	有限元模型	1591	3289	8233
	η_1/%	2.53	−0.73	1.71
2	模态测试	1551	3312	8101
	有限元模型	1604	3302	8299
	η_1/%	3.42	−0.32	2.45
3	模态测试	1548	3268	7972
	有限元模型	1611	3301	8244
	η_1/%	4.04	1.02	3.41
4	模态测试	1551	3239	7965
	有限元模型	1613	3286	8174
	η_1/%	4.01	1.44	2.62
5	模态测试	1550	3210	7867
	有限元模型	1609	3259	8112
	η_1/%	3.81	1.52	3.11

3.2　神经网络模型预测分析

对于如图 2 所示薄壁件离散单元结构，当结点厚度 t 取定值后，利用壳单元有限元模型，计算得到工件的前三阶固有频率，将其当作一个样本点，本文共计算得到 154 个样本，取其中 123 个样本作为训练样本。将模型训练学习率设置为 0.01，将训练数据打乱处理，并将 batch size 设置为 30。由于工件固有频率相对工件离散单元结点厚度较大，模型训练时，同一个 batch 中的所有样本的预测值相同，因此在模型训练之前对工件固有频率进行归一化处理，以一阶频率为例：

$$f_{\mathrm{N}}^{1} = \frac{f^{1} - f_{\min}^{1}}{f_{\max}^{1} - f_{\min}^{1}} \tag{16}$$

其中，f^1表示一阶频率，$f^1_{\min}$、$f^1_{\max}$分别表示所有样本一阶频率的最小值和最大值，f^1_{N}表示归一化的一阶频率。



a　一阶固有频率　　b　二阶固有频率　　c　三阶固有频率

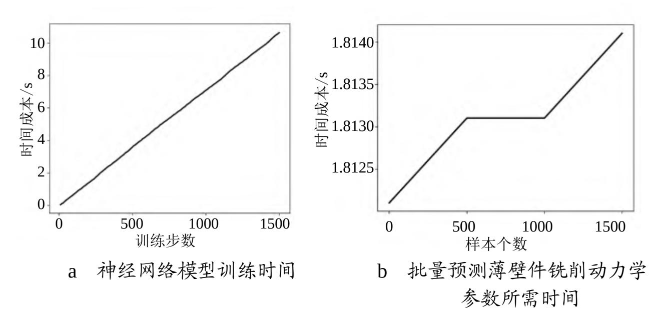
图 5　神经网络模型预测值收敛性分析

随着模型训练轮数的增加，工件前三阶固有频率通过收敛性情况如图 5 所示，由图可知，当 epoch 为 300 时，预测值达到收敛，因此本文取 epoch 为 300 进行计算。由神经网络模型和壳单元有限元模型计算得到的不同切削阶段工件固有频率的对比见表 2，当以壳单元有限元模型计算结果为基准时，由三层神经网络模型计算得到的前三阶固有频率最大误差为 0.409%，因此通过训练三层神经网络模型可以对切削过程中工件的动力学参数进行有效预测。

表 2　神经网络模型和有限元模型[16]计算的工件频率对比

切削状态	模态	1	2	3	切削状态	模态	1	2	3
1	有限元模型	1536	3002	7538	7	有限元模型	1589	3032	7370
	神经网络	1534	3004.5	7545.1		神经网络	1584	3037.1	7368.6
	η/%	−0.12	0.082	0.095		η/%	−0.31	0.168	−0.019
2	有限元模型	1512	2965	7523	8	有限元模型	1557	2957	7322
	神经网络	1510	2967	7526.4		神经网络	1556	2964.6	7333.7
	η/%	−0.11	0.067	0.046		η/%	−0.03	0.255	0.16
3	有限元模型	1553	3099	7806	9	有限元模型	1505	2881	7289
	神经网络	1549	3098	7821.4		神经网络	1509	2889.6	7296.3
	η/%	−0.29	−0.001	0.197		η/%	0.25	0.298	0.099
4	有限元模型	1581	3131	7748	10	有限元模型	1496	2954	7487
	神经网络	1576	3131.9	7766.3		神经网络	1500	2960.9	7517.1
	η/%	−0.30	0.0027	0.236		η/%	0.28	0.233	0.401
5	有限元模型	1598	3131	7624	11	有限元模型	1511	2970	7459
	神经网络	1593	3132.5	7628.7		神经网络	1514	2977.3	7489.5
	η/%	−0.31	0.047	0.062		η/%	0.20	0.247	0.409
6	有限元模型	1602	3095	7479	12	有限元模型	1519	2969	7400
	神经网络	1598	3094.3	7486.3		神经网络	1522	2977.6	7420.7
	η/%	−0. 23	−0. 023	0.098		η/%	0.23	0.291	0.28

对壳单元有限元模型和三层神经网络模型的计算效率进行对比。本文中薄壁件壳单元有限元模型的刚度矩阵和质量矩阵的自由度为 765，利用 matlab 软件进行特征方程求解，计算得到工件固有频率，对于一个样本，求解时间为 11.771 s。当 epoch 为 300，batch size 为 30 时，采用 CPU 进行计算，三层神经网络模型训练时间如图 6a 所示，训练时间约为 10 s。通过训练数据得到神经网络计算模型之后，利用模型可批量计算不同切削阶段工件的动力学参数，通过神经网络模型预测工件动力学参数的时间花销如图 6b 所示。神经网络模型和模型输入数据的加载时间约为 1.7760 s，当样本个数为 150 时，预测时间仅为 0.002 s。当采用 GPU 进行计算，模型训练时间仅为 4 s。



a 神经网络模型训练时间 b 批量预测薄壁件铣削动力学参数所需时间

图 6 神经网络模型时间

由以上分析可知，与壳单元有限元模型相比，利用神经网络的批量计算功能，在保证预测精度的前提下可大幅提高计算效率。

4 结束语

本文提出了一种基于三层神经网络的薄壁件铣削过程中工件时变动态参数预测的方法。首先将薄壁件离散化，以离散单元结点厚度为输入参数，工件前三阶固有频率为输出参数，构建三层神经网络，将壳单元有限元模型计算结果作为训练样本，得到神经网络模型。模态测试结果表明，所建立壳单元有限元模型对工件固有频率的最大预测误差约为 4%。当以有限元模型计算结果作为基准时，神经网络模型的最大预测误差为 0.409%。因此可认为与模态测试相比，神经网络模型的最大预测误差约为 4%。同时当训练样本为 132，epoch 为 300，batch size 为 30，采用 CPU 进行计算，三层神经网络模型训练时间约 10 s。利用模型批量计算不同切削阶段工件的动力学参数时，神经网络模型和模型输入数据的加载时间约 1.776 s，当预测切削状态个数为 150 时，预测时间仅为 0.002 s。因此，采用三层神经网络模型，在保证计算精度的前提下可大幅提高计算效率。在智能制造中，为对加工过程中的切削参数进行自适应优化，需要实时、准确获取切削过程中工件的动力学参数，利用本文建立的三层神经网络模型可以满足这一需求。

参考文献

[1] Yang Yun, Zhang Weihong, Ma Yingchao, et al. Chatter prediction for the peripheral milling of thin-walled workpieces with curved surfaces[J]. International Journal of Machine Tools and Manufacture, Elsevier, 2016, 109: 36−48.

[2] Yang Yun, Zhang Weihong, Ma Yingchao, et al. An efficient decomposition-condensation method for chatter prediction in milling large-scale thin-walled structures[J]. Mechanical Systems and Signal Processing, 2019, 121: 58−76.

[3] Dang Xuebin, Wan Min, Yang Yun, et al. Efficient prediction of varying dynamic characteristics in thin-wall milling using freedom and mode reduction methods[J]. International Journal of Mechanical Sciences, 2019, 150: 202−216.

[4] Budak E, Tun ç L T, Alan S, et al. Prediction of workpiece dynamics and its effects on chatter stability in milling[J]. CIRP annals, 2012, 61(1): 339−342.

[5] Zhang Xiaoming, Zhu Limin, Ding Han. Matrix perturbation method for predicting dynamic modal shapes of the workpiece in high-speed machining[J]. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 2010, 224(1): 177−183.

[6] Luo Ming, Zhang Dinghua, Wu Baohai, et al. Modeling and analysis effects of material removal on machining dynamics in milling of thin-walled workpiece[C]. Advanced Materials Research, 2011: 671−678 .

[7] Tian Weijun, Ren Junxue, Zhou Jinhua, et al. Dynamic modal prediction and experimental study of thin-walled workpiece removal based on perturbation method[J]. The International Journal of Advanced Manufacturing Technology, 2018, 94(5−8): 2099−2113.

[8] 鞠岗岗. 复杂曲面变厚度薄壁件多轴铣削失稳特性研究[D]. 济南：山东大学，2016.

[9] Tuysuz O, Altintas Y. Time-domain modeling of varying dynamic characteristics in thin-wall machining using perturbation and reduced-order substructuring methods[J]. Journal of Manufacturing Science and Engineering, 2018, 140(1): 011015.

[10] 刘一龙. 薄壁件铣削动力学分析与颤振监控方法[D]. 西安：西北工业大学，2017.

[11] Yeganefar A, Niknam S A, Asadi R. The use of support vector machine, neural network, and regression analysis to predict and optimize surface roughness and cutting forces in milling[J]. The International Journal of Advanced Manufacturing Technology, 2019, 105: 951−965.

[12] Pavlenko I, Saga M, Kuric I, et al. Parameter identification of cutting forces in crankshaft grinding using artificial neural networks[J]. Materials, 2020, 13(23): 5357.

[13] SK T, Shankar S, K D. Tool wear prediction in hard turning of EN8 steel using cutting force and surface roughness with artificial neural network[J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2020, 234(1): 329−342.

[14] Vasanth X A, Paul P S, Varadarajan A S. A neural network model to predict surface roughness during turning of hardened SS410 steel[J]. International Journal of System Assurance Engineering and Management, 2020, 11: 704−715.

[15] Wang Juncheng, Zou Bin, Liu Mingfang, et al. Milling force prediction model based on transfer learning and neural network[J]. Journal of Intelligent Manufacturing, 2021, 32: 947−956.

[16] Wang Dazhen, Ren Junxue, Tian Weijun, et al. Predicting the dynamics of thin-walled parts with curved surfaces in milling based on FEM and Taylor series[J]. The International Journal of Advanced Manufacturing Technology, 2019.